

## 1. AULA 4

### Variáveis Aleatórias Contínuas

1.1. **Variáveis Aleatórias Contínuas.** A título de introdução e para observar como os modelos contínuos aparecem naturalmente na prática, recordemos, do capítulo anterior, um exemplo:

**Exemplo 1.1.** Um engenheiro inspeciona determinada máquina em períodos discretos de tempo e observa se a máquina quebrou durante o período anterior. Independente do período, a probabilidade da máquina quebrar em determinado período é  $p, 0 < p < 1$ . A probabilidade da máquina não quebrar até o  $n$ -ésimo período foi calculada e é igual a  $(1 - p)^n$ .

Suponha, agora, que o engenheiro inspeciona a máquina continuamente no tempo e que as condições para que as falhas ocorram aleatoriamente sejam verdadeiras, isto é, se  $N(t)$  conta o número de falhas em  $(0, t]$ , as suposições I, II, III e IV, das ocorrências aleatórias no tempo, do capítulo anterior, são satisfeitas.

Se dividimos o intervalo  $(0, t]$  em intervalos infinitesimais da forma  $(\frac{kt}{n}, \frac{(k+1)t}{n}]$ ,  $0 \leq k \leq n - 1$ , de comprimento  $\frac{t}{n}$ , concluímos que, como na aproximação da distribuição binomial pela distribuição de Poisson demonstrada no Capítulo anterior,  $N(t)$ , o número de ocorrências em  $(0, t]$ , tem distribuição binomial de parâmetros  $n$  e  $p = \frac{\lambda t}{n} + o(\frac{t}{n})$ .

Seja, agora,  $T$  o tempo da ocorrência do primeiro evento de  $N(t)$ . Claramente, quando  $n \rightarrow \infty$ ,

$$P(T > t) = P(N(t) = 0) = (1 - \frac{\lambda t}{n} - o(\frac{t}{n}))^n \rightarrow \exp[-\lambda t].$$

Portanto, a função de distribuição de  $T$  é  $F_T(t) = 1 - \exp[-\lambda t]$ , da distribuição exponencial de parâmetro  $\lambda$ , definida em  $\mathfrak{R}^+$ , é contínua e que estudaremos, com mais detalhes, nas próximas seções.

Passemos à definição da variável aleatória contínua com argumentos semelhantes àqueles da definição das variáveis aleatórias discretas. Contudo, se o espaço amostral  $\Omega$  é o resultado de um experimento quantitativo contínuo, a imagem de  $\Omega$  através de uma função real  $X$  não é, certamente, enumerável e não podemos definir  $\mathfrak{S}_X$  como o conjunto das partes de  $X(\Omega)$ .

Para termos uma noção de como abordar a questão, observe que qualquer subconjunto dos números reais pode ser obtido através de operações, em um número finito ou infinito enumerável, de intervalos da forma  $(-\infty, t]$ . Entre outras operações, exemplificamos:

$$\begin{aligned}(t, \infty) &= \overline{(-\infty, t]}; \\ (s, t] &= (-\infty, t] - (-\infty, s], s < t; \\ \{t\} &= \bigcap_{n=1}^{\infty} (t - \frac{1}{n}, t + \frac{1}{n}).\end{aligned}$$

**Definição 1.2.** Definimos  $\beta$  como sendo a classe de subconjuntos dos reais obtida através das operações de reunião, intersecção, complementar, em número finito ou infinito, de subconjuntos na forma  $(-\infty, t], \forall t \in \mathfrak{R}$ .  $\beta$  é denominada  $\sigma$  álgebra de Borel na reta.

Nesta classe definimos a medida de probabilidade induzida pela variável aleatória  $X : \Omega \rightarrow \mathfrak{R}$ . Definimos a probabilidade induzida por  $X$ ,  $P_X$ , como  $P_X(B) = P(X^{-1}(B)), \forall B \in \beta$ , **quando**  $X$  satisfaz a seguinte definição:

**Definição 1.3.** Seja  $(\Omega, \mathfrak{S}, P)$  um espaço de probabilidade e  $X$  uma aplicação de  $\Omega$  nos reais ( $\mathfrak{R}$ ).  $X$  é uma variável aleatória contínua se  $X^{-1}((0, t]) \in \mathfrak{S}, \forall t \in \mathfrak{R}$ . Denominamos  $(\mathfrak{R}, \beta, P_X)$  como o espaço de probabilidade induzido por  $X$ .

Observe que  $P_X$  esta bem definida e

$$\begin{aligned}P_X((-\infty, t]) &= P(X^{-1}((-\infty, t])) = P(\{w : X(w) \in (-\infty, t]\}) = \\ &P(X \leq t) = F_X(t)\end{aligned}$$

é a função de distribuição da variável aleatória  $X$  que, neste caso, é uma função contínua.

Se a função de distribuição de  $X$  é diferenciável com  $\frac{dF_X(t)}{dt} = f_X(t)$ , definimos

**Definição 1.4.** Se  $X$  é uma variável aleatória contínua com função de distribuição

$$F_X(t) = \int_{-\infty}^t f_X(y) dy,$$

dizemos que  $f_X(t)$  é a função densidade de probabilidade de  $X$  e que  $X$  é contínua. A sua função de distribuição é denominada absolutamente contínua.

*Observação 1.5.* O valor  $F_X(t) = \int_{-\infty}^t f_X(y) dy$  não muda se  $f_X(y)$  apresentar um conjunto enumerável de ponto de descontinuidade de maneira que, diferente do caso discreto,  $F(x)$  não determina completamente a função densidade de probabilidade.

Observe que

$$f(x) = \frac{dF(x)}{dx} = \lim_{\Delta x \rightarrow 0} \frac{F(x + \Delta x) - F(x - \Delta x)}{2\Delta x}$$

e portanto

$$2\Delta x f(x) \approx P(x - \Delta x < X \leq x + \Delta x),$$

a probabilidade de que  $X$  está em um intervalo infinitesimal contendo o valor  $x$  é igual a  $f(x)$  vezes o seu comprimento, isto é, a área do retângulo de base de comprimento infinitesimal  $2\Delta x$  e altura  $f(x)$ .

É evidente que a função densidade de probabilidade é positiva, isto é,  $f_X(t) \geq 0, \forall t$ , que

$$\int_{-\infty}^{\infty} f(x) dx = 1$$

e que

$$P(a < X \leq b) = \int_a^b f(x) dx.$$

Na segunda aula, provamos que se  $X$  é uma variável aleatória, então

$$\forall \varepsilon > 0. \exists k \in \mathbb{N} : P(|X| > k) < \varepsilon.$$

e, usando este argumento, podemos provar que

$$\lim_{t \downarrow -\infty} f_X(t) = \lim_{t \uparrow \infty} f_X(t) = 0.$$

**Exemplo 1.6.** O custo mensal dos sinistros de uma Uma Cia. de Seguros é modelado por uma variável aleatória  $X$  com função densidade de probabilidade

$$f(x) = \begin{cases} 0 & : x < 0 \\ k \cdot (1+x)^{-4} & : 0 < x < \infty \end{cases},$$

onde  $k$  é uma constante.

Como devemos ter  $\int_{-\infty}^{\infty} f(x) dx = 1$  e

$$1 = k \int_0^{\infty} (1+x)^{-4} dx = -\frac{k}{3} (1+x)^{-3} \Big|_0^{\infty} = \frac{k}{3},$$

temos  $k = 3$ .

A função de distribuição de  $X$  é

$$F(x) = \begin{cases} 0 & : x < 0 \\ \int_0^x 3(1+y)^{-4} dy = 1 - (1+x)^{-3} & : x \geq 0 \end{cases}.$$

A probabilidade condicional de que o custo mensal ultrapasse 40 conhecendo-se que é maior do que 10 é

$$P(X > 40 | X > 10) = \frac{P(X > 40, X > 10)}{P(X > 10)} = \frac{P(X > 40)}{P(X > 10)} =$$

$$\frac{3 \int_{40}^{\infty} (1+y)^{-4} dy}{3 \int_{10}^{\infty} 3(1+y)^{-4} dy} = \left(\frac{11}{41}\right)^3 = 0,02.$$

Lembrando que as integrais de Riemann são limites de somas infinitesimais é natural que os parâmetros de uma variável aleatória contínua sejam definidos de maneira semelhante aos da variável aleatória discreta:

**Definição 1.7.** Se  $X$  é uma variável aleatória contínua com função densidade de probabilidade  $f(x)$ , definimos a média de  $X$ , que denotamos por  $E[X]$  ou  $\mu$ , à soma

$$\mu = \int_{-\infty}^{\infty} xf(x)dx,$$

onde a integral deve ser absolutamente convergente, caso contrário dizemos que a média não existe.

Por vezes estamos interessados em variáveis aleatórias que resultam da transformação de outra variável. Por exemplo, seja  $X$  uma variável aleatória e  $Y = g(X)$ , onde  $g$  é uma função real. Pense no esquema

$$(\Omega, \mathfrak{F}, P) \Rightarrow (\mathfrak{R}, \mathfrak{F}_X, P_X) \Rightarrow (\mathfrak{R}, \mathfrak{F}_{g(X)}, P_{g(X)}).$$

A medida  $P_{g(X)}$  é caracterizada por

$$P_{g(X)}((-\infty, y]) = P(g(X) \leq y) = \int_{\{x:g(x) \leq y\}} f_X(x)dx.$$

Pode-se provar que

$$E[g(X)] = E[Y] = \int_{-\infty}^{\infty} yf_Y(y)dy = \int_{-\infty}^{\infty} g(x)f_X(x)dx.$$

**Exemplo 1.8.** No exemplo anterior, em que

$$f(x) = \begin{cases} 0 & : x < 0 \\ 3.(1+x)^{-4} & : 0 < x < \infty \end{cases},$$

$$\mu = E[X] = 3 \int_0^{\infty} x(1+x)^{-4} dx = 3 \int_1^{\infty} (y-1)y^{-4} dy = 3 \cdot \left(\frac{1}{2} - \frac{1}{3}\right) = \frac{1}{2}.$$

$$E[X^2] = 3 \int_0^{\infty} x^2(1+x)^{-4} dx = 2 \int_0^{\infty} x(1+x)^{-3} dx = \frac{1}{3} \int_0^{\infty} (1+x)^{-2} dx = 1.$$

Em particular a esperança da  $n$ -ésima potência de variável aleatória, se existir, é denominada momento.

**Definição 1.9.** Seja  $X$  uma variável aleatória contínua. O  $n$ -ésimo momento de  $X$ , denotado por  $\mu_n$  é definida como:

$$\mu_n = E[X^n] = \int_{-\infty}^{\infty} x^n f(x) dx, \text{ se existir.}$$

Observe que  $\mu_1 = \mu = E[X]$ . A esperança de potências da forma  $E[(X - \mu)^n]$  são denominadas momentos centrais.

**Definição 1.10.** Seja  $X$  uma variável aleatória contínua com média  $\mu$ . O  $n$ -ésimo momento central de  $X$ , denotado por  $\sigma_n$  é definida como:

$$\sigma_n = E[(X - \mu)^n] = \int_{-\infty}^{\infty} (x - \mu)^n f(x) dx, \text{ se existir.}$$

Em particular o segundo momento central em torno da média é a variância, interpretada como uma dispersão em torno da média.

**Definição 1.11.** Se  $X$  é uma variável aleatória contínua com média  $\mu$  e função de densidade de probabilidade  $f(x)$ , definimos a variância de  $X$ , que denotamos por  $E[(X - \mu)^2] = \sigma^2$ , à integral

$$\sigma_2 = \sigma^2 = \int_{-\infty}^{\infty} (x - \mu)^2 f(x) dx.$$

relembrando que a integral deve ser absolutamente convergente, caso contrário dizemos que a variância não existe.

*Observação 1.12.* Como no caso discreto, é fácil provar que  $\sigma^2 = Var(X) = E[X^2] - \mu^2$ . O desvio padrão de  $X$  é definido pela raiz quadrada de  $\sigma^2$ . No exemplo anterior temos que  $Var(X) = 1 - \frac{1}{4} = \frac{3}{4}$  e  $dP(X) = \frac{\sqrt{3}}{2}$ .

**Definição 1.13.** Se  $X$  é uma variável aleatória contínua. A função geradora de momentos de  $X$ ,  $M_X(t)$ , é o valor esperado  $E[\exp[tX]]$ , se existir, em um intervalo simétrico,  $(-s, s)$ , de números reais.

$$M_X(t) = E[\exp[tX]] = \int_{-\infty}^{\infty} \exp[tx] f(x) dx.$$

**Exemplo 1.14.** Em uma Cia. de manufaturas, as perdas por danos à propriedade segue uma distribuição contínua com função densidade de probabilidade  $f(y) = 0,02 \exp[-0,02y]$ ,  $y > 0$ . A função geradora de momentos de  $Y$  é

$$M_Y(t) = E[\exp[tY]] = \int_0^{\infty} \exp[ty] 0,02 \exp[-0,02y] dy =$$

$$\int_0^{\infty} 0,02 \exp[(t - 0,02)y] dy = \frac{0,02}{0,02 - t}$$

, se  $t < 0,02$ .

A primeira derivada de  $M_Y(t)$  é  $M_Y^{(1)}(t) = \frac{0,02}{(0,02-t)^2}$  e

$$E[Y] = M_Y^{(1)}(0) = \frac{1}{0,02}.$$

A segunda derivada de  $M_Y(t)$  é  $M_Y^{(2)}(t) = \frac{2 \cdot (0,02)}{(0,02-t)^3}$  que no número 0 vale

$$E[Y^2] = M_Y^{(2)}(0) = \frac{2}{(0,02)^2}.$$

Portanto a variância de  $Y$  é  $\sigma^2 = E[Y^2] - E[Y]^2 = \frac{1}{(0,02)^2}$ .

*Observação 1.15.* As desigualdades de Markov, Chebyshev e de Jensen continuam valendo no caso de variáveis aleatórias contínuas e as provas são semelhantes.

**1.2. Modelos Probabilísticos Contínuos.** Como no capítulo anterior, descreveremos modelos probabilísticos contínuos aplicáveis nas ciências atuariais:

### Distribuição uniforme.

Em um espaço amostral discreto e finito, a distribuição uniforme associa a cada elemento amostral a mesma probabilidade. Em um modelo contínuo cada ponto tem probabilidade igual a zero e a distribuição uniforme se caracteriza associando a cada intervalo de mesmo comprimento a mesma probabilidade. A variável aleatória  $X$  tem distribuição uniforme em um intervalo finito,  $(a, b]$ , de números reais se sua função densidade de probabilidade é :

$$f(x) = \begin{cases} \frac{1}{b-a} & : a < x \leq b \\ 0 & : \text{c.c.} \end{cases}.$$

A esperança de  $X$  é

$$\mu = E[X] = \int_a^b \frac{x}{b-a} dx = \frac{1}{b-a} \frac{x^2}{2} \Big|_a^b = \frac{(b-a) \cdot (b+a)}{2(b-a)} = \frac{a+b}{2}.$$

Tambem temos

$$E[X^2] = \int_a^b \frac{x^2}{b-a} dx = \frac{1}{b-a} \frac{x^3}{3} \Big|_a^b = \frac{(b-a) \cdot (b^2 + ab + a^2)}{3(b-a)} = \frac{b^2 + ab + a^2}{3}$$

e portanto

$$\text{Var}(X) = \sigma^2 = E[X^2] - \mu^2 = \frac{b^2 + ab + a^2}{3} - \left(\frac{a+b}{2}\right)^2 = \frac{(b-a)^2}{12}.$$

A função de distribuição de  $X$  é

$$F(x) = \begin{cases} 0 & : x < a \\ \frac{x-a}{b-a} & : a \leq x < b \\ 1 & : x \geq b \end{cases}.$$

e a função geradora de momentos

$$M_X(t) = E[\exp[tX]] = \int_a^b \frac{\exp[tX]}{b-a} dx = \frac{\exp[tb] - \exp[ta]}{t(b-a)}.$$

**Exemplo 1.16.** Uma seguradora de automóveis cobra R\$250,00 pela franquia de determinada apólice e paga o máximo de R\$1.500,00 por uma perda total. Se o custo dos sinistros, em relação à apólice, é modelado por uma distribuição uniforme no intervalo  $(0, 2.000]$ , qual a probabilidade de um pagamento de perda total? Qual a probabilidade do segurado não usar a apólice?

Se  $X$  é a variável custo, tem distribuição uniforme no intervalo  $(0, 2000]$ , com função densidade de probabilidade

$$f(x) = \begin{cases} \frac{1}{2.000} & : 0 < x \leq 2.000 \\ 0 & : \text{c.c.} \end{cases}.$$

A probabilidade de um pagamento de perda total é

$$P(X > 1.500) = \int_{1.500}^{2000} \frac{1}{2.000} dx = 0,25.$$

Entendemos que o segurado não usa a apólice quando a franquia é maior do que o custo do conserto e portanto, com probabilidade

$$P(X \leq 250) = \int_0^{250} \frac{1}{2.000} dx = 0,125.$$

### Distribuição de Cauchy.

A variável aleatória de Cauchy é caracterizada pela função densidade de probabilidade

$$f(x) = \frac{1}{\pi\beta\{1 + [(\frac{x-\alpha}{\beta})]^2\}}, \quad -\infty < x < \infty,$$

com parâmetros  $\alpha$ ,  $-\infty < \alpha < \infty$  e  $\beta$ ,  $\beta > 0$ .

Em particular se  $\alpha = 0$  e  $\beta = 1$  temos a função densidade de probabilidade da distribuição de Cauchy padrão:

$$f(x) = \frac{1}{\pi\{1+x^2\}}, \quad -\infty < x < \infty,$$

Observe que  $\frac{d}{dx} \arctg(x) = \frac{1}{1+x^2}$  e portanto

$$\begin{aligned} \frac{1}{\pi} \int_{-\infty}^{\infty} \frac{1}{1+x^2} dx &= \lim_{M \rightarrow \infty} \int_{-M}^M \frac{1}{1+x^2} dx = \\ &= \frac{1}{\pi} \lim_{M \rightarrow \infty} [\arctg(M) - \arctg(-M)] = \frac{1}{\pi} \left[ \frac{\pi}{2} + \frac{\pi}{2} \right] = 1 \end{aligned}$$

com função de distribuição

$$F(x) = \frac{1}{\pi} \int_{-\infty}^x \frac{1}{1+x^2} dx = \frac{1}{2} + \frac{1}{\pi} \arctg(x).$$

A distribuição de Cauchy é ilustrativa pois é exemplo de uma distribuição cujos momentos não existem, por exemplo

$$\begin{aligned} E[|X|] &= \frac{1}{\pi} \int_{-\infty}^{\infty} \frac{|x|}{1+x^2} dx = \\ &= \frac{2}{\pi} \int_0^{\infty} \frac{x}{1+x^2} dx = \frac{\ln(1+x^2)}{\pi} \Big|_0^{\infty} = \infty \end{aligned}$$

### Distribuição exponencial.

Como no caso discreto, uma variável aleatória contínua fica completamente caracterizada através de sua função de distribuição. Introduzimos a distribuição exponencial:

**Definição 1.17.** Uma variável aleatória  $T$  tem função de distribuição exponencial se, e somente se,

$$F_T(t) = \begin{cases} 0 & : t < 0 \\ 1 - \exp[-\lambda t] & : t \geq 0 \end{cases}.$$

$$F_T(t) = 1 - \exp[-\lambda.t].$$

$F_T(t)$  é diferenciável e tem função densidade de probabilidade

$$f(t) = \begin{cases} 0 & : t < 0 \\ \lambda \exp[-\lambda t] & : t \geq 0 \end{cases}.$$

A função geradora de momentos de  $T$  é dada por

$$M_T(t) = E[\exp[t.T]] = \int_0^{\infty} \exp[tx] \lambda \exp[-\lambda.x] dx =$$



$$\int_0^{\infty} \lambda \exp[-x \cdot (\lambda - t)] dx = \frac{\lambda}{\lambda - t}, t < \lambda.$$

com primeira e segunda derivadas iguais a  $M_T^{(1)}(t) = \frac{\lambda}{(\lambda - t)^2}$  e  $M_T^{(2)}(t) = \frac{2 \cdot \lambda \cdot (\lambda - t)}{(\lambda - t)^4}$ , respectivamente. No ponto zero temos

$$\mu = E[T] = M_T^{(1)}(0) = \frac{1}{\lambda}$$

e  $E[T^2] = M_T^{(2)}(0) = \frac{2}{\lambda^2}$  de forma que

$$\sigma^2 = Var(T) = \frac{2}{\lambda^2} - \frac{1}{\lambda^2} = \frac{1}{\lambda^2}.$$

Observe que a média de  $T$  é o inverso de seu parâmetro.

**Exemplo 1.18.** Uma Cia. de Seguros tem observado que o custo dos sinistros de aeronaves de porte médio é modelado por uma variável aleatória com função de distribuição

$$F(t) = \begin{cases} 0 & : t < 0 \\ 1 - \exp[-0,001t] & : t \geq 0 \end{cases}.$$

isto é,  $X$  tem distribuição exponencial. A probabilidade de um sinistro com custo maior do que 4.000 é

$$P(X > 4.000) = 0,001 \int_{4.000}^{\infty} \exp[-0,001x] dx = \exp[-4] = 0,018.$$

Se escolhermos casualmente 389 aeronaves seguradas, qual a probabilidade de que entre elas 10 reclamem sinistros com custos maiores do que 4.000? Se  $Y$  é definida como o número de aeronaves, dentre as 389, que reclamem sinistros com custos maiores do que 4.000,  $Y$  tem distribuição binomial com parâmetros  $n = 389$  e  $p = 0,018$  e  $P(Y = 10) = \binom{389}{10} (0,018)^{10} (0,982)^{379}$ , de cálculo difícil. Como  $n = 389$  é grande e  $p = 0,018$  é pequeno podemos aproximar a distribuição binomial pela distribuição de Poisson com média, a mesma de binomial,  $\lambda = n \cdot p = 389 \cdot 0,018 = 7$ . Assim, se  $N$  tem distribuição de Poisson com  $\lambda = 7$ ,

$$P(Y = 10) = P(N = 10) = \frac{\exp[-7] 7^{10}}{10!} = 0,07.$$

Introduzimos este capítulo exemplificando que a distribuição exponencial é uma extensão contínua da distribuição geométrica e como tal, também apresenta a propriedade de falta de memória. Uma variável aleatória  $T$  contínua e positiva que modela, por exemplo, o tempo de

funcionamento de um componente eletrônico tem a propriedade de falta de memória se, e somente se,

$$P(T > t + s | T > s) = P(T > t),$$

onde  $P(T > t) = 1 - P(T \leq t)$ .

**Teorema 1.19.** *T é uma variável aleatória contínua com a propriedade de falta de memória se, e somente se, T tem distribuição exponencial.*

**Prova** Se denotamos  $g(t) = P(T > t)$  temos que  $0 \leq g(t) \leq 1$  e que  $g(t + s) = g(t)g(s)$ .

Para todo número natural  $n$ , temos

$$g(n) = g(1 + 1 + \dots + 1) = g(1).g(1)\dots.g(1) = g(1)^n.$$

Portanto  $g(1) \neq 1$  pois, caso contrário, teríamos  $0 = \lim_{n \uparrow \infty} g(n) = \lim_{n \uparrow \infty} g(1)^n = 1$ , que é uma contradição.

Em adição

$$g(1) = g\left(\frac{n}{n}\right) = g\left(\frac{1}{n} + \frac{1}{n} + \dots + \frac{1}{n}\right) = g\left(\frac{1}{n}\right)^n,$$

o que implica  $g\left(\frac{1}{n}\right) = g(1)^{\frac{1}{n}}$ .

Portanto  $g(1) \neq 0$  pois, caso contrário, teríamos  $1 = \lim_{n \uparrow \infty} g\left(\frac{1}{n}\right) = \lim_{n \uparrow \infty} g(1)^{\frac{1}{n}} = 0$ , que também é uma contradição.

Concluimos então que  $0 < g(1) < 1$  e que existe um número real positivo  $\lambda$ , a imagem inversa de  $g(1)$  através da função exponencial  $f(x) = \exp[-x]$  tal que  $g(1) = \exp[-\lambda]$

Pelo mesmo argumento, se  $n$  e  $m$  são números naturais

$$g\left(\frac{n}{m}\right) = g\left(\frac{1}{m} + \frac{1}{m} + \dots + \frac{1}{m}\right) = g\left(\frac{1}{m}\right)^n = g(1)^{\frac{n}{m}},$$

e concluímos que  $g(x) = \exp[-\lambda x]$ ,  $\forall x \in \mathbf{Q}$ , onde  $\mathbf{Q}$  é o conjunto dos números racionais. Como  $\mathbf{Q}$  é denso em  $\mathfrak{R}$ , temos

$$g(t) = P(T > t) = \exp[-\lambda t], \forall t \in \mathfrak{R}^+.$$

Consequentemente, a função de distribuição de  $T$  é

$$F(t) = \begin{cases} 0 & : t < 0 \\ 1 - \exp[-\lambda t] & : t \geq 0 \end{cases}.$$

que caracteriza completamente a distribuição exponencial.  $\lambda > 0$  é o parâmetro da distribuição.

Vale o reverso, isto é, se  $T$  tem distribuição exponencial, temos

$$P(T > t+s) = \exp[-\lambda(t+s)] = \exp[-\lambda t] \cdot \exp[-\lambda s] = P(T > t) \cdot P(T > s)$$

e  $T$  tem falta de memória.

**Exemplo 1.20.** Uma industria fabrica lâmpadas especiais que ficam continuamente em operação. Caso a lâmpada dure menos do que 50 horas oferece a seus clientes a garantia de reposição. O tempo de vida útil dessas lâmpadas é modelado através da distribuição exponencial com parâmetro  $\frac{1}{8.000}$ . Portanto, a proporção de lâmpadas trocadas por garantia é

$$P(T \leq 50) = \int_0^{50} \frac{1}{8.000} \exp\left[-\frac{t}{8.000}\right] dt = 1 - \frac{1}{8.000} \exp\left[-\frac{50}{8.000}\right] = 0,006.$$

Você acha razoável substituir uma lâmpada que já durou 5.000 horas? Como sabemos que a distribuição exponencial tem a propriedade da falta de memória, a resposta é não pois uma lâmpada usada é tão boa quanto uma nova. Analiticamente podemos escrever

$$P(T > t + 5.000 | T > 5.000) = \frac{P(T > t + 5.000, T > 5.000)}{P(T > 5.000)} = \frac{\exp\left[-\frac{1}{8.000}(t + 5.000)\right]}{\exp\left[-\frac{1}{8.000}5.000\right]} = \exp\left[-\frac{1}{8.000}t\right] = P(T > t).$$

### Distribuição de Pareto.

**Definição 1.21.** A função de distribuição de uma variável aleatória  $X$ , com função de distribuição de Pareto,  $F(x)$  é definida por:

$$F(x) = 1 - \left(\frac{\theta}{x + \theta}\right)^\alpha \quad x > 0,$$

Onde  $\alpha > 0$  é o parâmetro da forma e  $\theta > 0$  é o parâmetro de escala de sua função densidade de probabilidade

$$f(x) = \frac{\alpha\theta^\alpha}{(x + \theta)^\alpha}, \quad x > 0.$$

Portanto a esperança de  $X$  é

$$\begin{aligned} E[X] &= \int_0^\infty x f(x) dx = \int_0^\infty \left( \int_0^x dy \right) f(x) dx = \int_0^\infty \left( \int_y^\infty f(x) dx \right) dy = \\ &= \int_0^\infty P(X > y) dy = \int_0^\infty \frac{\theta^\alpha}{(y + \theta)^\alpha} dy = \\ &= \theta^\alpha \int_\theta^\infty \frac{1}{y^\alpha} dy = \frac{\theta}{\alpha - 1}, \quad \text{se } \alpha > 1. \end{aligned}$$

Em geral vale

$$E[X^k] = \frac{\theta^k k!}{(\alpha - 1) \cdot (\alpha - 2) \cdots (\alpha - k)}, \quad \text{para } \alpha > k.$$

Concluimos que a variância da distribuição de Pareto é

$$\sigma^2 = \text{Var}(X) = E[X^2] - E[X]^2 = \frac{2\theta^2}{(\alpha-1)(\alpha-2)} - \left(\frac{\theta}{\alpha-1}\right)^2.$$

O  $p$ -ésimo percentil de  $X$ ,  $x_p$ , é definido pela relação

$$F(x_p) = 1 - \left(\frac{\theta}{x_p + \theta}\right)^\alpha = p$$

que tem solução

$$x_p = \theta \cdot \left((1-p)^{-\frac{1}{\alpha}} - 1\right).$$

**Exemplo 1.22.** A perda aleatória,  $X$ , com seguro é modelada por uma distribuição de Pareto com média  $\mu = 100.000$  e variância igual a  $3 \cdot (10)^{10}$  unidades monetárias. Os parâmetros da distribuição podem ser calculados equacionando  $\frac{\theta}{\alpha-1} = 100.000$  e  $\frac{2\theta^2}{(\alpha-1)(\alpha-2)} - (100.000)^2 = 3 \cdot (10)^{10}$  com solução  $\alpha = 3$  e  $\theta = 200.000$ .

O atuário pode estimar a perda mediana calculando

$$x_{0,5} = 200.000 \cdot \left((0,5)^{-\frac{1}{3}} - 1\right) = 52.000$$

e também se prevenir contra a pior perda definida por

$$E[X] + 3\sigma = 100.000 + 3 \cdot \sqrt{3 \cdot (10)^{10}} = 619.615,24$$

com probabilidade  $P(X > 619.616,24) = \left(\frac{200.000}{619.615,24 + 200.000}\right)^3 = 0,0145$ .

Se  $X$  é uma variável aleatória com distribuição de Pareto, a variável aleatória  $Y = X + \theta$  assume valores  $y > \theta$  e tem função de distribuição

$$P(Y \leq y) = P(X + \theta \leq y) = P(X \leq y - \theta) = 1 - \left(\frac{\theta}{y}\right)^\alpha \quad y > \theta.$$

Neste caso,  $\theta$  não é considerado um parâmetro, pois qualquer troca do valor de  $\theta$  altera o domínio da distribuição definida em  $[\theta, \infty)$  e  $y$  define a distribuição de Pareto uniparamétrica.

**Exemplo 1.23.** O tempo de vida de um sistema eletrônico depois de submetido a um processo de burn-in é modelado por uma distribuição de Pareto definida no intervalo  $[1, \infty)$  com média  $\mu = 5$ .

Portanto o parâmetro  $\alpha$  é definido pela equação

$$E[Y] = \int_1^\infty y \frac{\alpha}{y^{\alpha+1}} dy = -\frac{\alpha}{\alpha-1} \Big|_1^\infty = \frac{\alpha}{\alpha-1},$$

resultando o valor  $\alpha = 1,2$ .

A probabilidade que o sistema sobreviva a 7 unidades de tempo é:

$$P(Y > 7) = \int_7^{\infty} \frac{1,2}{y^{2,2}} dy = 0,1.$$

### Distribuição de Weibull.

**Definição 1.24.** Uma variável aleatória  $T$  com função de distribuição  $F(t)$

$$F(t) = 1 - \exp[-(\lambda.t)^\tau] \quad t > 0$$

onde  $\tau > 0$  é o parâmetro da forma e  $\lambda > 0$  é o parâmetro de escala, tem função densidade de probabilidade

$$f(t) = \frac{dF(t)}{dt} = \lambda^\tau \tau t^{\tau-1} \exp[-(\lambda.t)^\tau], \quad t > 0$$

e é denominada distribuição de Weibull.

*O momento de ordem  $k$ , de  $T$  pode ser calculado:*

$$\begin{aligned} E[T^k] &= \int_0^{\infty} t^k f(t) dt = \int_0^{\infty} k \left( \int_0^t s^{k-1} ds \right) f(t) dt = \\ &k \int_0^{\infty} P(T > s) s^{k-1} ds = k \int_0^{\infty} \exp[-(\lambda.s)^\tau] s^{k-1} ds. \end{aligned}$$

*Substituindo  $z = (\lambda.s)^\tau$ , temos  $s = \frac{z^{\frac{1}{\tau}}}{\lambda}$  e  $ds = \frac{1}{\lambda.\tau} . z^{\frac{1}{\tau}-1} . dz$ .*

*Portanto*

$$E[T^k] = \frac{1}{\lambda^k} \frac{k}{\tau} \Gamma\left(\frac{k}{\tau}\right) = \frac{1}{\lambda^k} \Gamma\left(\frac{k}{\tau} + 1\right)$$

*onde a função Gama é definida como anteriormente:  $\Gamma(t) = \int_0^{\infty} z^{t-1} \exp[-z] dz$ ,  $t > 0$ .*

*Consequentemente temos que*

$$E[T] = \frac{1}{\lambda} \Gamma\left(\frac{1}{\tau} + 1\right)$$

$$E[T^2] = \frac{1}{\lambda^2} \Gamma\left(\frac{2}{\tau} + 1\right)$$

*e*

$$\sigma^2 = \frac{1}{\lambda^{2.\tau}} \left[ 2\Gamma\left(\frac{2}{\tau}\right) - \frac{1}{\tau} \left(\Gamma\left(\frac{1}{\tau}\right)\right)^2 \right].$$

**Exemplo 1.25.** Se  $T$  é uma variável aleatória representando uma perda, com função de distribuição

$$F(t) = 1 - \exp[-(0,02.t)^2] \quad t > 0,$$

calcule a perda média, a variância da perda e a probabilidade de que a perda não ultrapasse um desvio padrão da média.

A perda média é dada por

$$\mu = E[T] = \frac{1}{0,02} \Gamma\left(\frac{1}{2} + 1\right) = 50 \cdot \frac{\sqrt{\pi}}{2} = 44,3,$$

$$E[T^2] = \frac{1}{(0,02)^2} \Gamma\left(\frac{2}{2} + 1\right) = 2500$$

e

$$\sigma^2 = E[T^2] - (E[T])^2 = 2500 - (44,3)^2 = 537,5$$

com desvio padrão  $\sigma = 23,2$ .

A probabilidade de que  $T$  não ultrapasse  $\mu + \sigma = 67,5$  é  $F(67,5) = 1 - \exp[-(0,02 \cdot 67,5)^2] = 0,84$ .

### Distribuição Normal.

**Definição 1.26.** Dizemos que uma variável aleatória  $X$  tem distribuição normal com parâmetros  $\mu$  e  $\sigma^2$ , e denotamos  $X \sim N(\mu, \sigma^2)$ , se  $X$  tem função densidade de probabilidade

$$f(x) = \frac{1}{\sigma\sqrt{2\pi}} \exp\left[-\frac{(x - \mu)^2}{2\sigma^2}\right], \quad -\infty < x < \infty, \quad \sigma > 0, \quad -\infty < \mu < \infty.$$

*A expressão de  $f(x)$  parece complexa mas tem um gráfico suave em forma de um sino.*

*Figura 7.1 - Gráfico da curva normal*

*O parâmetro  $\mu$  é de escala e o gráfico de normais com mesmo  $\sigma$  e diferentes  $\mu$  são como segue:*

*Figura 7.2 - Gráficos de curvas normais*

O parâmetro  $\sigma^2$  é o da forma da densidade e quanto maior o  $\sigma$  a densidade é mais dispersa em torno de  $\mu$  e existe chances maiores de encontrar valores, da variável, distantes de  $\mu$ . Se  $\sigma$  é pequeno, a densidade tem forma mais concentrada em torno de  $\mu$  e a chance de observarmos valores próximos de  $\mu$  aumenta.

Na realidade estamos definindo uma classe de distribuições normais pois a cada número real  $\mu$  e número real positivo  $\sigma$ , temos uma distribuição normal. Em particular a distribuição normal com  $\mu = 0$  e  $\sigma^2 = 1$ , denominada de distribuição normal padrão e denotada por  $Z \sim N(0, 1)$  tem função densidade de probabilidade

$$f(x) = \frac{1}{\sqrt{2\pi}} \exp\left[-\frac{x^2}{2}\right], \quad -\infty < x < \infty.$$

Para ter uma noção da complexidade analítica de tal expressão provemos que

$$I = \int_{-\infty}^{\infty} \frac{1}{\sqrt{2\pi}} \exp\left[-\frac{x^2}{2}\right] dx = 1.$$

Para proceder com a prova notemos que  $I > 0$  e que  $I = 1$  se e somente se,  $I^2 = 1$ . Contudo

$$\begin{aligned} I^2 &= \left( \int_{-\infty}^{\infty} \frac{1}{\sqrt{2\pi}} \exp\left[-\frac{x^2}{2}\right] dx \right) \cdot \left( \int_{-\infty}^{\infty} \frac{1}{\sqrt{2\pi}} \exp\left[-\frac{y^2}{2}\right] dy \right) = \\ &= \int_{-\infty}^{\infty} \int_{-\infty}^{\infty} \frac{1}{2\pi} \exp\left[-\frac{1}{2}(x^2 + y^2)\right] dx dy. \end{aligned}$$

Neste ponto consideramos uma transformação para coordenadas polares através das equações

$$x = \rho \sin \theta \quad e \quad y = \rho \cos \theta, \quad 0 \leq \theta \leq 2\pi, \quad 0 < \rho < \infty,$$

produzindo

$$I^2 = \frac{1}{2\pi} \int_0^{2\pi} \int_0^{\infty} \exp\left[-\frac{1}{2}\rho^2\right] \rho d\rho d\theta =$$

$$\frac{1}{2\pi} \int_0^{2\pi} \int_0^{\infty} \exp[-y] dy d\theta = \frac{1}{2\pi} \int_0^{2\pi} d\theta = 1.$$

A função de distribuição dessa variável,  $Z \sim N(0, 1)$ , é dada por

$$F(z) = \int_{-\infty}^z \frac{1}{\sqrt{2\pi}} \exp\left[-\frac{x^2}{2}\right] dx$$

mas o cálculo analítico para tal expressão é mais complexo do que os cálculos anteriores e devemos utilizar técnicas numéricas. Na prática, simplificamos com o uso das tabelas estatísticas, apresentadas no final do livro.

A tabela fornece a área sob a função densidade de probabilidade entre o valor zero 0 e um valor real  $z$  à sua direita. O valor  $z$ , até sua primeira casa decimal é encontrado na primeira coluna e sua segunda casa decimal na primeira linha da tabela. O cruzamento dessa linha e coluna, no interior da tabela, nos dá a probabilidade  $P(0 < Z \leq z)$ . Procedendo dessa maneira verificamos, por exemplo:

*Figura 7.3 - Cálculo de probabilidades*



$$P(0 < Z \leq 1,64) = 0,45;$$

$$P(0 < Z \leq 1,96) = 0,475.$$

Desde que a função densidade de probabilidade da distribuição normal padrão é perfeitamente simétrica em relação a zero, concluímos que;

$$P(Z \leq -1,64) = P(Z \geq 1,64) = 0,5 - P(0 < Z \leq 1,64) = 0,05;$$

$$P(-1,96 \leq Z \leq 1,96) = 2.P(0 < Z \leq 1,96) = 0,95;$$

$$P(-1,64 \leq Z \leq 1,96) = P(-1,64 \leq Z \leq 0) + P(0 < Z \leq 1,96) = \\ P(0 < Z \leq 1,64) + P(0 < Z \leq 1,96) = 0,975.$$

Reversamente, podemos encontrar o valor de  $z$ , tal que a área (probabilidade) à sua esquerda, ou direita seja fixada. Consideremos encontrar  $z$ , tal que  $P(Z \leq z) = 0,8$ . Observe que este valor de  $z$  deve ser positivo, caso contrário, a área à sua esquerda seria menor ou igual a 0,5. Como  $z$  é positivo podemos escrever

$$P(Z \leq z) = P(Z \leq 0) + P(0 < Z \leq z) = 0,5 + P(0 < Z \leq z) = 0,8,$$

que implica  $P(0 < Z \leq z) = 0,3$ . Observando o valor mais próximo de 0,3 no corpo da tabela, percorremos sua linha e sua coluna, no sentido contrário do que vínhamos fazendo, No caso obtemos  $z = 0,85$ .

Para encontrar o valor de  $z$  com  $P(Z \leq z) < 0,5$  podemos proceder com os mesmos argumentos, por exemplo:

Se  $P(Z \leq z) = 0,05$ , temos que  $z$  é negativo e que  $P(Z \geq -z) = 0,05$ . Portanto  $P(0 < Z \leq -z) = 0,45$  e concluímos que  $-z = 1,64$  e  $z = -1,64$ .

Conhecemos que a distribuição de uma variável aleatória é completamente determinada pela sua função geradora de momentos,  $M_Z(t)$ , quando esta função existir. A função geradora de momentos de  $Z$  é

$$M_Z(t) = E[\exp[tZ]] = \int_{-\infty}^{\infty} \frac{1}{\sqrt{2\pi}} \exp[tz] \exp[-\frac{z^2}{2}] dz = \\ \exp[\frac{t^2}{2}] \int_{-\infty}^{\infty} \frac{1}{\sqrt{2\pi}} \exp[-\frac{(z-t)^2}{2}] dz = \exp[\frac{t^2}{2}].$$

Podemos calcular a média e a variância de  $Z$  através da sua função geradora de momentos. A primeira derivada de  $M_Z(t)$  é igual a  $M_Z^{(1)}(t) = t \cdot \exp[\frac{t^2}{2}]$  com  $\mu = E[Z] = M_Z^{(1)}(0) = 0$ .

A segunda derivada de  $M_Z(t)$  é  $M_Z^{(2)}(t) = \exp[\frac{t^2}{2}] + t^2 \cdot \exp[\frac{t^2}{2}]$  que no ponto zero vale  $E[Z^2] = M_Z^{(2)}(0) = 1$ . Portanto  $\sigma^2 = \text{var}(Z) = E[Z^2] - \mu^2 = 1$ .

Se consideramos a transformação linear da variável aleatória  $Z$ ,  $X = \sigma \cdot Z + \mu$  onde  $\mu$  é um número real e  $\sigma$ , um número real positivo, temos que a função geradora de momentos de  $X$  é

$$M_X(t) = E[\exp[tX]] = E[\exp[t(\sigma \cdot Z + \mu)]] = E[\exp[t \cdot \sigma \cdot Z] \exp[t \cdot \mu]] = \exp[t \cdot \mu] M_Z(t \cdot \sigma) = \exp[t \cdot \mu + \frac{t^2 \sigma^2}{2}].$$

Acontece que tal função geradora de momentos caracteriza completamente a distribuição normal com média  $\mu$  e variância  $\sigma^2$ . Calculando as derivadas da função geradora de momentos no ponto zero, obtemos  $E[X] = M_X^{(1)}(0) = \mu$  e  $E[X^2] = M_X^{(2)}(0) = \sigma^2 + \mu^2$  e concluímos que os parâmetros da distribuição Normal, denotada por  $X \sim N(\mu, \sigma^2)$  são sua média e variância.

Inversamente, podemos considerar a transformação reversa,  $Z = \frac{X - \mu}{\sigma} = \frac{X}{\sigma} - \frac{\mu}{\sigma}$  e temos

$$M_Z(t) = E[\exp[t \cdot Z]] = E[\exp[t \cdot (\frac{X}{\sigma} - \frac{\mu}{\sigma})]] = \exp[-t \cdot \frac{\mu}{\sigma}] \cdot M_X(\frac{t}{\sigma}) = \exp[-\frac{t^2}{2}].$$

Concluímos que existe uma equivalência entre a normal de média  $\mu$  e variância  $\sigma^2$ ,  $N(\mu, \sigma^2)$ , e a normal padrão,  $N(0, 1)$ , através das citadas transformações e utilizaremos este resultado para cálculos envolvendo a função de distribuição de  $X \sim N(\mu, \sigma^2)$  através da função de distribuição da normal padrão  $Z \sim N(0, 1)$ .

Assim, se  $X \sim N(\mu, \sigma^2)$ , a sua função de distribuição pode ser calculada como

$$F_X(x) = P(X \leq x) = P(\frac{X - \mu}{\sigma} \leq \frac{x - \mu}{\sigma}) = P(Z \leq \frac{x - \mu}{\sigma}) = F_Z(\frac{x - \mu}{\sigma}).$$

**Exemplo 1.27.** O custo dos sinistros de certo tipo de apólice tem distribuição normal com média de R\$1.800,00 e desvio padrão R\$400,00. A probabilidade de que um sinistro escolhido aleatoriamente custe mais do que R\$1.500,00 é

$$P(X > 1500) = P(\frac{X - \mu}{\sigma} > \frac{1500 - 1800}{400}) = P(Z > -0,75) =$$

$$P(Z \leq 0,75) = 0,5 + P(0 < Z \leq 0,75) = 0,5 + 0,27337 = 0,77.$$

A probabilidade de que o custo esteja entre R\$1.500,00 e R\$2.000,00 é

$$\begin{aligned} P(1500 < X \leq 2000) &= P\left(\frac{1500 - 1800}{400} < \frac{X - \mu}{\sigma} \leq \frac{2000 - 1800}{400}\right) = \\ &= P(-0,75 < Z \leq 0,5) = P(-0,75 < Z \leq 0) + P(0 < Z \leq 0,5) = \\ &= P(0 < Z \leq 0,75) + 0,19146 = 0,27337 + 0,19146 = 0,46. \end{aligned}$$

A probabilidade de que o custo esteja a 1,96 desvio padrão de sua média é

$$\begin{aligned} P(|X - 1800| \leq 1,96 \cdot 400) &= P(-1,96 \cdot 400 \leq X - 1800 \leq 1,96 \cdot 400) = \\ &= P(-1,96 \leq \frac{X - 1800}{400} \leq 1,96) = P(-1,96 \leq Z \leq 1,96) = 0,95. \end{aligned}$$

Caso a Cia de Seguros deseje estabelecer uma franquia de forma que 10% das ocorrências não utilizem o seguro, devemos procurar o custo  $x$  tal que  $P(X \leq x) = 0,1$ .

Padronizando  $X$ , a equação é equivalente a

$$\begin{aligned} P\left(\frac{X - \mu}{\sigma} \leq \frac{x - 1800}{400}\right) &= 0,1 \leftrightarrow P\left(Z \leq \frac{x - 1800}{400}\right) = 0,1 \leftrightarrow \\ P\left(Z \geq \frac{x - 1800}{400}\right) &= 0,1 \leftrightarrow P\left(0 < Z \leq \frac{1800 - x}{400}\right) = \\ 0,4 \leftrightarrow \frac{1800 - x}{400} &= 1,64 \leftrightarrow x = 1.144, \end{aligned}$$

isto é, a franquia deve ser de R\$1.144,00.

**Observação 1.28. Aproximação da distribuição binomial pela distribuição normal.**

Consideramos no exemplo 1.8 do Capítulo anterior o cálculo da probabilidade de que entre 10.000 segurados, 15 solicitem benefícios devido à ocorrências de sinistros. A probabilidade da ocorrência de tais sinistros foi estipulada como  $p = 0,001$ . Se  $Y$  é a variável aleatória definida pelo número de segurados que reclamam os benefícios, temos que  $Y$  tem distribuição binomial de parâmetros 10.000 e 0,001 ( $Y \sim B(10.000, 0,001)$ ).

A probabilidade do evento  $\{Y = 15\}$  é

$$P(Y = 15) = \binom{10.000}{15} 0,001^{15} 0,999^{9985},$$

de cálculo complicado. Naquele exemplo aproximamos tal probabilidade pela probabilidade da distribuição de Poisson com mesma média da distribuição binomial. Neste Capítulo consideramos a aproximação

da distribuição binomial pela distribuição normal com mesma média e variância da binomial.

Para um melhor entendimento consideremos a distribuição binomial de parâmetros  $n = 10$  e  $p = 0,5$ . A função de probabilidade da variável aleatória  $Y \sim B(10; 0,5)$  é

$y$	0	1	2	3	4	5
$P(Y = y)$	0,001	0,01	0,044	0,117	0,205	0,246
$y$	6	7	8	9	10	
$P(Y = y)$	0,205	0,117	0,044	0,01	0,001	

com representação gráfica:

Figura 7.4- Aproximação da binomial pela normal

Uma primeira aproximação gráfica de uma variável discreta por uma variável contínua é através do histograma, o gráfico de retângulos contíguos cujas áreas somam 1. Se para cada valor da variável discreta construirmos um retângulo de base 1 e altura igual à sua probabilidade teremos a soma dessas áreas igual a 1. A base do retângulo correspondente ao valor  $x_i$ , da variável, é definida por  $x_i - 0,5$  e  $x_i + 0,5$ , como na figura acima.

Seja  $X$  a variável aleatória que corresponde ao histograma. No caso em que  $n$  é grande a variável  $X$  converge para uma variável normal com média  $\mu = np$  e  $\sigma^2 = n.p.(1 - p)$ , a média e variância da distribuição  $B(n, p)$ .

No exemplo em que  $n = 10$  e  $p = 0,5$  temos  $P(Y = 5) = 0,246$ ,  $P(Y \leq 3) = 0,172$  e  $P(2 \leq Y < 6) = 0,612$ .

Se  $X \sim N(5; 2, 5)$ ,

$$P(4,5 \leq X \leq 5,5) = P\left(\frac{4,5 - 5}{1,58} \leq \frac{X - 5}{1,58} \leq \frac{5,5 - 5}{1,58}\right) =$$

$P(-0,32 \leq Z \leq 0,32) = 2 \cdot P(0 \leq Z \leq 0,32) = 2 \cdot 0,12552 = 0,251$ ,  
uma aproximação por menos de 5 milésimos.

$$P(X \leq 3,5) = P\left(\frac{X - 5}{1,58} \leq \frac{3,5 - 5}{1,58}\right) = P(Z \leq -0,95) =$$

$$P(Z > 0,95) = 0,5 - P(0 \leq Z \leq 0,95) = 0,5 - 0,32894 = 0,171.$$

$$P(1,5 \leq X \leq 5,5) = P\left(\frac{1,5 - 5}{1,58} \leq \frac{X - 5}{1,58} \leq \frac{5,5 - 5}{1,58}\right) =$$

$$P(-2,21 \leq Z \leq 0,32) = P(0 \leq Z \leq 2,21) +$$

$$P(0 \leq Z \leq 0,32) = 0,48645 + 0,12552 = 0,61.$$

A aproximação colocada tem justificativa rigorosa quando demonstramos o Teorema do Limite Central que aproxima soma de variáveis aleatórias independentes e identicamente distribuídas por uma distribuição normal. Observe que uma variável binomial pode ser interpretada como soma de Bernoulli que são independentes e identicamente distribuídas.

Portanto, considerando o exemplo 8 do Capítulo anterior, poderíamos aproximar  $Y \sim B(10.000; 0,001)$  pela distribuição normal  $X \sim N(10; 9,99)$  e

$$P(Y = 15) \approx P(14,5 \leq X \leq 15,5) = P\left(\frac{14,5 - 10}{3,16} \leq \frac{X - 10}{3,16} \leq \frac{15,5 - 10}{3,16}\right) =$$

$$P(1,4 \leq Z \leq 1,74) = P(Z \leq 1,74) - P(Z \leq 1,4) = 0,45907 - 0,41924 = 0,0398.$$

O resultado da aproximação pela distribuição de Poisson foi 0,0347.

**Teorema 1.29.** *Se  $Z$  é uma variável aleatória contínua com distribuição normal com média  $\mu = 0$  e variância  $\sigma^2 = 1$ , a variável aleatória  $Y$ , resultado da transformação  $Y = Z^2$ , tem função densidade de probabilidade*

$$f(y) = \frac{1}{\sqrt{\pi}} \frac{1}{\sqrt{y}} \exp\left[-\frac{y}{2}\right], \quad y > 0,$$

*denominada de distribuição qui-quadrado com um grau de liberdade.*

**Prova** *Evidentemente, os valores de  $Y$  são positivos e a função de distribuição de  $Y$  é dada por*

$$P(Y \leq y) = P(Z^2 \leq y) = P(-\sqrt{y} \leq Z \leq \sqrt{y}) =$$

$$\int_{-\sqrt{y}}^{\sqrt{y}} \frac{1}{\sqrt{2\pi}} \exp\left[-\frac{x^2}{2}\right] dx = 2 \cdot \int_0^{\sqrt{y}} \frac{1}{\sqrt{2\pi}} \exp\left[-\frac{x^2}{2}\right] dx.$$

Portanto a função densidade de probabilidade de  $Y$ ,  $f(y) = \frac{dF(y)}{dy}$  é

$$f(y) = \frac{1}{\sqrt{\pi}} \frac{1}{\sqrt{y}} \exp\left[-\frac{y}{2}\right], \quad y > 0,$$

### Distribuição qui-quadrado.

**Definição 1.30.** A função de distribuição de uma variável aleatória  $Y$  com função densidade de probabilidade

$$f(y) = \frac{1}{\Gamma\left(\frac{k}{2}\right)} \left(\frac{1}{2}\right)^{\frac{k}{2}} y^{\frac{k}{2}-1} \exp\left[-\frac{y}{2}\right], \quad y > 0,$$

é denominada de distribuição qui-quadrado com  $k$  graus de liberdade, tem média  $\mu = k$  e variância  $\sigma^2 = 2k$ .

A função Gama, denotada por  $\Gamma$  que aparece na definição acima é definida por

$$\Gamma(t) = \int_0^{\infty} x^{t-1} \exp[-x] dx, \quad t > 0.$$

Por integração por partes pode-se provar que  $\Gamma(t+1) = t\Gamma(t)$ . Se  $t = n$ , um número natural, temos  $\Gamma(n+1) = n!$ . Em particular  $\Gamma\left(n + \frac{1}{2}\right) = \frac{1 \cdot 3 \cdot 5 \cdots (2n-1)}{2^n} \sqrt{2\pi}$  e  $\Gamma\left(\frac{1}{2}\right) = 2 \cdot \Gamma\left(\frac{3}{2}\right) = \sqrt{\pi}$ .

### Distribuição gama.

**Definição 1.31.** A função de distribuição de uma variável aleatória  $X$  com função densidade de probabilidade

$$f(x) = \frac{1}{\Gamma(\alpha)} \lambda^\alpha x^{\alpha-1} \exp[-\alpha x], \quad x > 0,$$

é denominada de distribuição gama com parâmetros  $\alpha$  e  $\lambda$ , os quais são números reais positivos.

A distribuição gama é denotada por  $\text{gama}(\alpha, \lambda)$  e tem média  $E[X] = \frac{\alpha}{\lambda}$  e variância  $\sigma^2 = \frac{\alpha}{\lambda^2}$ .

### Distribuição Beta.

Uma variável aleatória caracterizada pela função densidade de probabilidade

$$f(x) = \frac{1}{B(a, b)} x^{a-1} (1-x)^{b-1}, \quad 0 < x < 1,$$

onde  $a > 0$  e  $b > 0$  tem função de distribuição denominada Beta de parâmetros  $a$  e  $b$ . A função é definida por

$$B(a, b) = \int_0^1 x^{a-1} (1-x)^{b-1} dx = \frac{\Gamma(a)\Gamma(b)}{\Gamma(a+b)}$$

e portanto  $\int_0^1 f(x) dx = 1$ .

**Teorema 1.32.** *Se  $X$  é uma variável aleatória com distribuição Beta, de parâmetros  $a$  e  $b$ , então*

$$E[X^k] = \frac{\Gamma(k+a)\Gamma(a+b)}{\Gamma(a)\Gamma(k+a+b)}.$$

*Prova*

$$\begin{aligned} E[X^k] &= \frac{1}{B(a, b)} \int_0^1 x^{k+a-1} (1-x)^{b-1} dx = \frac{B(k+a, b)}{B(a, b)} = \\ &= \frac{\Gamma(k+a)\Gamma(b)}{\Gamma(k+a+b)} \cdot \frac{\Gamma(a+b)}{\Gamma(a)\Gamma(b)} = \\ &= \frac{\Gamma(k+a)\Gamma(a+b)}{\Gamma(a)\Gamma(k+a+b)} \end{aligned}$$

e concluímos a prova.

Usando o teorema temos

$$E[X] = \frac{\Gamma(1+a)\Gamma(a+b)}{\Gamma(a)\Gamma(1+a+b)} = \frac{a}{a+b},$$

$$E[X^2] = \frac{\Gamma(2+a)\Gamma(a+b)}{\Gamma(a)\Gamma(2+a+b)} = \frac{(a+1)a}{(a+b+1)(a+b)},$$

e

$$\text{Var}(X) = \frac{(a+1)a}{(a+b+1)(a+b)} - \left(\frac{a}{a+b}\right)^2 = \frac{ab}{(a+b+1)(a+b)^2}.$$

Um resultado interessante relaciona a distribuição binomial e a distribuição beta:

$$\sum_{j=k}^n \binom{n}{j} p^j (1-p)^{n-j} = \frac{1}{B(k, n-k+1)} \int_0^p x^{k-1} (1-x)^{n-k} dx.$$

*Prova*

Por integração por partes, se

$$v = (1 - x)^{n-k} \Rightarrow dv = (n - k)(1 - x)^{n-k-1}(-1)dx$$

e se

$$du = x^{k-1}dx \Rightarrow u = \frac{x^k}{k}$$

, temos:

$$\begin{aligned} & \frac{1}{B(k, n - k + 1)} \int_0^p x^{k-1}(1 - x)^{n-k} dx = \\ & \frac{1}{B(k, n - k + 1)} \left\{ \frac{p^k}{k} (1 - p)^{n-k} + \left( \frac{n - k}{k} \right) \int_0^p x^k (1 - x)^{n-k-1} dx \right\} = \end{aligned}$$

Observando que  $\frac{1}{B(k, n-k+1)} = \binom{n}{k} k$  e repetindo o processo de integração por partes temos:

$$\begin{aligned} & \binom{n}{k} p^k (1 - p)^{n-k} + \binom{n}{k+1} [p^{k+1} (1 - p)^{n-k-1} + \\ & \frac{n!}{(k+1)!(n-k-2)!} \int_0^p x^{k+1} (1 - x)^{n-k-2} dx = \\ & \dots = \sum_{j=k}^n \binom{n}{j} p^j (1 - p)^{n-j}. \end{aligned}$$

### Observação 1.33. Transformações de variáveis aleatórias

O Teorema 6.28 pode ser colocado como um caso particular do Teorema que segue:

**Teorema 1.34.** *Suponha que  $X$  é uma variável aleatória do tipo contínuo com função de densidade de probabilidade  $f_X(x)$ , com domínio  $\mathfrak{R}_X = \{x : f_X(x) > 0\}$ . Assuma que:*

a)  $y = g(x)$  define uma transformação um a um e sobrejetora de  $\mathfrak{R}_X$  em  $\mathfrak{R}_Y = \{y : g(y) > 0\}$ .

b) A derivada de  $x = g^{-1}(y)$ , com respeito a  $y$  é contínua em  $\mathfrak{R}_Y$ .

Então  $Y = g(X)$  é uma variável aleatória do tipo contínuo com função de densidade de probabilidade

$$f_Y(y) = \left| \frac{dg^{-1}(y)}{dy} \right| \cdot f_X(g^{-1}(y)), \quad y \in \mathfrak{R}_Y.$$

*Prova*

Se  $g(x)$  é crescente,  $g^{-1}(y)$  é crescente. Então



$$F_Y(y) = P(Y \leq y) = P(g(X) \leq y) = P(X \leq g^{-1}(y)) = F_X(g^{-1}(y))$$

e portanto

$$f_Y(y) = \frac{dF_X(g^{-1}(y))}{dy} = \left| \frac{dg^{-1}(y)}{dy} \right| \cdot f_X(g^{-1}(y)).$$

No caso em que  $g(x)$  é decrescente,  $g^{-1}(y)$  é decrescente e

$$F_Y(y) = P(Y \leq y) = P(g(X) \leq y) = P(X \geq g^{-1}(y)) = 1 - F_X(g^{-1}(y))$$

e

$$f_Y(y) = \frac{dF_X(g^{-1}(y))}{dy} = \left| \frac{dg^{-1}(y)}{dy} \right| \cdot f_X(g^{-1}(y)).$$

A restrição de que  $y = g(x)$  seja bijetiva no domínio  $\mathfrak{R}_X$  é restritiva. Se podemos particionar  $\mathfrak{R}_X$  em  $\mathfrak{R}_X^1, \mathfrak{R}_X^2, \dots, \mathfrak{R}_X^m$  de maneira que em cada  $\mathfrak{R}_X^i$ ,  $g(x)$  é bijetora, podemos aplicar o Teorema em cada  $\mathfrak{R}_X^i$  e concluir que

$$f_Y(y) = \sum_{i=1}^m \left| \frac{dg^{i-1}(y)}{dy} \right| \cdot f_X(g^{i-1}(y)), \quad y \in \mathfrak{R}_Y.$$

**Teorema 1.35.** *Se  $X$  é uma variável aleatória contínua com distribuição normal com média  $\mu$  e variância  $\sigma^2$ , a variável aleatória  $Y$ , resultado da transformação  $Y = \exp[X]$ , tem função densidade de probabilidade*

$$f(y) = \frac{1}{y \cdot \sigma \cdot \sqrt{2\pi}} \exp\left[-\frac{(\ln y - \mu)^2}{2\sigma^2}\right], \quad y > 0.$$

denominada de distribuição log-normal.

**Prova** É evidente que os valores  $y$  que  $Y$  assume são positivos. A função de distribuição de  $Y$  é

$$F(y) = P(Y \leq y) = P(\exp[X] \leq y) = P(X \leq \ln y) =$$

$$\int_{-\infty}^{\ln y} \frac{1}{\sigma \sqrt{2\pi}} \exp\left[-\frac{(x - \mu)^2}{2\sigma^2}\right] dx.$$

Portanto, a função densidade de probabilidade de  $Y$  é

$$f(y) = \frac{dF(y)}{dy} = \frac{1}{y \cdot \sigma \cdot \sqrt{2\pi}} \exp\left[-\frac{(\ln y - \mu)^2}{2\sigma^2}\right].$$

**Definição 1.36.** A função de distribuição de uma variável aleatória  $Y$  com função densidade de probabilidade

$$f(y) = \frac{1}{y \cdot \sigma \cdot \sqrt{2\pi}} \exp\left[-\frac{(-\mu)^2}{2\sigma^2}\right], \quad y > 0,$$

é denominada de distribuição Lognormal com parâmetros  $\mu$  e  $\sigma^2$ .

Recordemos que a função geradora de momentos da variável aleatória  $X \sim N(\mu, \sigma^2)$  é

$$M_X(t) = E[\exp[t \cdot X]] = \exp\left[t \cdot \mu + \frac{\sigma^2 t^2}{2}\right].$$

Portanto

$$E[Y] = E[\exp[X]] = M_X(1) = \exp\left[\mu + \frac{\sigma^2}{2}\right],$$

$$E[Y^2] = E[\exp[2 \cdot X]] = \exp[2 \cdot \mu + 2 \cdot \sigma^2]$$

e

$$\sigma_Y^2 = \exp[2 \cdot \mu + 2 \cdot \sigma^2] - \exp[2 \cdot \mu + \sigma^2].$$

**Exemplo 1.37.** A taxa de crescimento de uma população é uma variável aleatória  $Y$  com distribuição normal com média 0,03 e variância 0,0001. O crescimento da população, com tamanho inicial de 100.000 indivíduos no período de um ano é modelado por  $Y = 100.000 \exp[X]$ . Reconhecemos que a variável  $\frac{Y}{100.000}$  tem distribuição lognormal com os mesmos parâmetros de  $X$  e portanto, no período de um ano esperamos uma população de

$$E[Y] = 100.000 \cdot E[\exp[X]] = 100.000 \exp\left[0,03 + \frac{0,0001}{2}\right] = 103.051.$$

*E-mail address:* bueno@ime.usp.br

DEPARTAMENTO DE ESTATÍSTICA, INSTITUTO DE MATEMÁTICA E ESTATÍSTICA,  
UNIVERSIDADE DE SÃO PAULO, CAIXA POSTAL 66281, CEP 05311-970, SÃO  
PAULO, BRAZIL